

PRONÓSTICO DE VENTAS DE ENERGÍA Y USUARIOS REGULADOS DE LA EMPRESA  
DE ENERGÍA DE PEREIRA

DIANA ALEJANDRA HERNANDEZ MOLINA

UNIVERSIDAD TECNOLÓGICA DE PEREIRA

FACULTAD DE INGENIERÍA: INGENIERÍA ELECTRICA, ELECTRÓNICA, FÍSICA Y  
CIENCIAS DE LA COMPUTACIÓN

PROGRAMA DE INGENIERÍA ELECTRICA

PEREIRA

2018

PRONÓSTICO DE VENTAS DE ENERGÍA Y USUARIOS REGULADOS DE LA EMPRESA  
DE ENERGÍA DE PEREIRA

DIANA ALEJANDRA HERNANDEZ MOLINA

Para optar a título de ingeniera electricista

Director

Harold Salazar Isaza

UNIVERSIDAD TECNOLÓGICA DE PEREIRA

FACULTAD DE INGENIERÍA: INGENIERÍA ELECTRICA, ELECTRÓNICA, FÍSICA Y  
CIENCIAS DE LA COMPUTACIÓN

PROGRAMA DE INGENIERÍA ELECTRICA

PEREIRA

2018

Nota de aceptación

---

---

---

---

---

---

---

Presidente del jurado

---

jurado

---

jurado

## DEDICATORIA

*A mi mamá y mis hermanitos, Cris y Nico.*

## **AGRADECIMIENTOS**

A mi mamá, abuela y abuelo porque gracias a sus esfuerzos, apoyo y amor pude culminar esta etapa de mi vida.

A Fabián Ríos por estar siempre cuando te necesito, apoyarme y animarme.

A Cristian, Cesar, Fabio, Felipe, Luis, Nelly y Viviana, por todas las horas de estudio, por el tiempo compartido y especialmente por su amistad incondicional.

A mi profesor guía, Harold Salazar por su apoyo, dedicación y paciencia durante mi trabajo de grado y durante las clases dictadas que tuve el gusto de recibir.

A Juan David Caicedo y Felipe Muñoz por su apoyo y confianza durante todo el proyecto y mi tiempo de práctica.

## CONTENIDO

1.	RESUMEN.....	12
2.	INTRODUCCIÓN .....	13
3.	OBJETIVOS.....	14
3.1.	OBJETIVO GENERAL .....	14
3.2.	OBJETIVOS ESPECÍFICOS .....	14
4.	METODOLOGÍA .....	15
5.	ANÁLISIS DE LA SITUACIÓN ACTUAL .....	16
5.1.	DATOS HISTORICOS .....	16
5.1.1.	Ventas totales de energía para el mercado regulado .....	16
5.1.2.	Número de usuarios totales facturados en el mercado regulado EEP .....	25
5.2.	MODELOS ACTUALES DE LA EMPRESA DE ENERGÍA DE PEREIRA .....	28
5.3.	MODELOS ACTUALES DE OTRAS EMPRESAS DEL SECTOR.....	29
6.	MARCO TEÓRICO .....	30
6.1.	MÉTODOS UNIVARIADOS .....	30
6.1.2.	Regresión exponencial .....	31
6.1.3.	Regresión logarítmica .....	31
6.1.4.	Regresión cuadrática .....	32
6.1.5.	Promedios móviles .....	32
6.1.6.	ARIMA.....	33
6.1.7.	WINTERS .....	34
6.2.	INTELIGENCIA ARTIFICIAL .....	35
6.2.1.	Redes Neuronales Artificiales.....	35
•	Arquitectura De La Red Neuronal Artificial .....	36

• Tipo de aprendizaje de la red neuronal.....	37
7. CRITERIOS DE VALIDACIÓN DE LOS METODOS.....	38
7.1. Error residual .....	38
7.2. Mean Absolute Desviation - Error Absoluto Medio (MAD) .....	38
7.3. Root Mean Squared Error – Raíz del Error Cuadrático Medio (RMSE).....	38
7.4. Mean Absolute Percentage Error – error cuadrado medio (MAPE) .....	39
8. ESTUDIO DE VARIABLES PARA PRONÓSTICO DE VENTAS DE ENERGÍA .....	40
8.1. VARIABLES RELEVANTES .....	40
8.2. CORRELACIÓN ENTRE VARIABLES .....	40
9. APLICACIÓN DE MODELOS PARA PRONÓSTICO DE VENTAS DE ENERGÍA .....	42
9.1. APLICACIÓN DE MODELOS UNIVARIADOS DE TENDENCIA .....	42
9.2. APLICACIÓN DE METODO DE WINTERS .....	43
9.3. APLICACIÓN DE REDES NEURONALES ARTIFICIALES .....	43
9.3.1. Pronóstico Clase de Servicio Residencial .....	44
9.3.2. Pronóstico Clase de Servicio Comercial .....	45
9.3.3. Pronóstico Clase de Servicio Industrial .....	45
9.3.4. Pronóstico Clase de Servicio Oficial, Áreas Comunes y Provisional .....	46
9.3.5. Pronóstico Clase de Servicio Alumbrado Público .....	47
10. APLICACIÓN DE MODELOS UNIVARIADOS Y ESTADÍSTICOS PARA PROYECCIÓN DE USUARIOS .....	49
11. COMPARACIÓN DE LOS RESULTADOS OBTENIDOS CON LOS DIFERENTES METODOS.....	51
11.1. COMPARACIÓN DE RESULTADOS OBTENIDOS PARA PRONÓSTICO DE VENTAS DE ENERGÍA POR CLASE DE SERVICIO .....	51
11.2. COMPARACIÓN DE RESULTADOS OBTENIDOS PARA PROYECCIÓN DE USUARIOS.....	52

12.	CONCLUSIONES .....	53
13.	BIBLIOGRAFÍA.....	54
	ANEXO A.....	56



## LISTA DE FIGURAS

Figura 1. Datos históricos de ventas de energía mercado regulado de la Empresa de Energía de Pereira 2010-2016 .....	17
Figura 2. Ventas de energía Clase Residencial 01-2010 a 10-2017 .....	18
Figura 3. Dispersión de la estacionalidad de Ventas de energía de la Clase Residencial .....	19
Figura 4. Ventas de energía Clase Áreas Comunes 01-2010 a 10-2017 .....	19
Figura 5. Dispersión de la estacionalidad de Ventas de energía de la Clase Áreas Comunes .....	20
Figura 6. Ventas de energía Clase Comercial 01-2010 a 10-2017 .....	20
Figura 7. Dispersión de la estacionalidad de Ventas de energía de la Clase Comercial .....	21
Figura 8. Ventas de energía Clase Industrial 01-2010 a 10-2017 .....	21
Figura 9. Dispersión de la estacionalidad de Ventas de energía de la Clase Industrial .....	22
Figura 10. Ventas de energía Clase Oficial 01-2010 a 10-2017 .....	22
Figura 11. Dispersión de la estacionalidad de Ventas de energía de la Clase Oficial .....	23
Figura 12. Ventas de energía Clase Provisionales 01-2010 a 10-2017 .....	23
Figura 13. Dispersión de la estacionalidad de Ventas de energía de la Clase Provisional .....	24
Figura 14. Ventas de energía Clase Alumbrado Público 01-2010 a 10-2017 .....	24
Figura 15. Dispersión de la estacionalidad de Ventas de energía de la Clase Alumbrado Público .....	25
Figura 16. Serie histórica de número de usuarios de la clase residencial .....	26
Figura 17. Serie histórica de número de usuarios de la clase áreas comunes .....	26
Figura 18. Serie histórica de número de usuarios de la clase comercial .....	27
Figura 19. Serie histórica de número de usuarios de la clase industrial.....	27
Figura 20. Serie histórica de número de usuarios de la clase oficial .....	28
Figura 21. Serie histórica de número de usuarios de la clase provisionales .....	28
Figura 22. Regresión lineal simple.....	30
Figura 23. Regresión exponencial .....	31
Figura 24. Regresión logarítmica .....	31
Figura 25. Regresión cuadrática.....	32
Figura 26. Estructura de una red neuronal artificial [5] .....	35
Figura 27. Red con una única capa, R elementos de entrada y S neuronas [5].....	36

Figura 28. Proceso de ajuste de pesos en el aprendizaje supervisado [5] .....37

Figura 29. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Residencial 11-2017 a 12-2022.....44

Figura 30. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Comercial 11-2017 a 12-2022.....45

Figura 31. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Industrial 11-2017 a 12-2022 .....46

Figura 32. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Otros 11-2017 a 12-2022 .....47

Figura 33. Serie histórica 01-2011 a 10-2017 y pronóstico de ventas de la clase de servicio Alumbrado Público 11-2017 a 12-2022 .....48

## LISTA DE TABLAS

Tabla I. Variación anual porcentual de ventas de energía del mercado de EEP del periodo 2010 a 2016.....	17
Tabla II. Variación anual porcentual de número de usuarios del mercado de EEP del periodo 2010 a 2016 .....	25
Tabla III. Correlación entre variables de entrada y cada clase de servicio .....	41
Tabla IV. Resultados de aplicación de métodos univariados simples a la serie histórica de ventas de energía por clase de servicio.....	42
Tabla V. Resultados de la aplicación del método de Winters por clase de servicio .....	43
Tabla VI. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase residencial.....	44
Tabla VII. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase comercial .....	45
Tabla VIII. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase industrial.....	46
Tabla IX. Resultados de aplicación de RNA a la serie histórica de ventas de energía de las clases áreas comunes, oficial y provisionales .....	47
Tabla X. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase alumbrado público.....	48
Tabla XI. Resultados de proyección de usuarios del mercado regulado EEP por clase de servicio .....	50
Tabla XII. Comparación de resultados obtenidos con los diferentes métodos aplicados para pronóstico de ventas de energía .....	51
Tabla XIII. Comparación de resultados obtenidos con los diferentes métodos aplicados para proyección de usuarios .....	52

## **1. RESUMEN**

En el presente trabajo de grado se encuentra el desarrollo de diferentes modelos con el fin de realizar pronóstico de ventas de energía eléctrica y número de usuarios para el mercado regulado de la Empresa de Energía de Pereira (EEP), estos modelos se implementan para cada clase de servicio del mercado regulado EEP, empleando datos históricos de enero de 2010 a octubre de 2017, los cuales son divididos en dos subconjuntos el primero para modelamiento de datos y el segundo para validación; posteriormente se realiza una respectiva comparación entre los resultados arrojados por estos utilizando los criterios de validación MAPE (error porcentual absoluto medio) y MAD (desviación absoluta media), entre los cuales los mejores resultados para ventas de energía son los obtenidos mediante redes neuronales artificiales y para número de usuarios en la mayoría de clases de servicio mediante método de tendencia cuadrática.

La Empresa de Energía de Pereira divide su mercado regulado en 7 clases de servicio; residencial, áreas comunes, comercial, industrial, oficial, alumbrado público y provisionales, las cuales presentan un comportamiento diferente tanto para ventas de energía como para número de usuarios, por lo tanto para observar el comportamiento de cada una de estas series, se presentan por separado.

Para el desarrollo e implementación de los métodos de pronóstico se hace uso de los softwares Minitab 17 y MATLAB V2013a. Se realiza el modelamiento de los datos de las series de ventas de energía y número de usuarios del mercado regulado de la Empresa de Energía de Pereira empleando el software Minitab 17, con el fin de realizar pruebas de normalidad, análisis univariado, y correlación de las series a tratar con posibles variables para implementar métodos multivariados, los cuales se aplican con el software MATLAB V2013a.

## 2. INTRODUCCIÓN

En los últimos años el sector eléctrico se ha visto influenciado por los avances tecnológicos, el incremento de usuarios y el desarrollo económico, lo que ha generado un incremento en la demanda de energía eléctrica; no obstante otros fenómenos como los cambios climáticos y sus consecuencias han logrado concientizar un poco a la población en cuanto al consumo eficiente de energía eléctrica, lo que ha ocasionado un decrecimiento en la demanda a pesar de que el número de usuarios mantiene una tendencia creciente. Debido a que todas estas variables influyen en la tendencia de la demanda, para las empresas del sector eléctrico, plantear un modelo para pronosticar demanda y ventas de energía se ha convertido en una tarea un poco dispendiosa que requiere modelos más robustos en los que se puedan incluir todas estas variables para no incurrir en proyecciones erróneas.

La Empresa de Energía de Pereira (EEP), cuenta con tres figuras: generador, distribuidor y comercializador, por lo tanto proyectar la demanda, perdidas y ventas en energía, como también el número de usuarios, entre otras variables, es de vital importancia para prever la cantidad de energía que se debe generar y/o comprar, para presupuestar y proyectar obras de expansión de la red eléctrica, para presupuestar los ingresos generales de la empresa, por lo tanto es esencial contar con un modelos para proyecciones que sean muy acertados.

Por parte de la Gerencia Comercial de la Empresa de Energía de Pereira, se debe realizar pronóstico de ventas de energía y de usuarios, tanto para el mercado regulado como para el no regulado, puesto que los resultados de estos pronósticos son el insumo principal para tomar decisiones en cuanto a presupuesto. A pesar de esto el ejercicio de pronóstico para ventas del mercado no regulado difiere de las ventas del mercado regulado debido a que los usuarios del mercado no regulado presentan estacionalidades y curvas de demanda con características muy típicas según la actividad económica que realice el usuario. Este trabajo está orientado únicamente a pronosticar la venta de energía y el número de usuarios para el mercado regulado ya que más del 70% de las ventas de energía de la empresa corresponden a usuarios de este mercado en las diferentes clases de servicio que presta la empresa, siendo los usuarios de clase residencial los más representativos de este mercado.

### **3. OBJETIVOS**

#### **3.1. OBJETIVO GENERAL**

Desarrollar y comparar modelos para el pronóstico de ventas de energía y usuarios regulados de la Empresa de Energía de Pereira.

#### **3.2. OBJETIVOS ESPECÍFICOS**

- Revisar los métodos utilizados por la empresa para el pronóstico de ventas de energía y de usuarios.
- Conocer los métodos utilizados por otras empresas del sector eléctrico y la literatura referente al pronóstico de demanda, potencia, ventas y usuarios.
- Aplicar diferentes modelos para pronóstico de ventas de energía y usuarios regulados de la Empresa de Energía de Pereira.
- Aplicar métricas para evaluar la calidad de los resultados obtenidos con los diferentes métodos.
- Comparar los resultados obtenidos con los diferentes métodos aplicados para el pronóstico de ventas de energía y usuarios.

## 4. METODOLOGÍA

Para el desarrollo del presente proyecto se dividirá el proceso en las siguientes actividades:

**4.1. Actividad 1. Revisión del estado del arte.** En esta etapa se llevará a cabo una revisión de los métodos utilizados actualmente por la empresa para el pronóstico de ventas de energía y de usuarios y se revisará en la literatura los modelos utilizados para realizar pronósticos de series temporales.

**4.2. Actividad 2. Selección de datos y eliminación de outliers.** Se solicitan al área encargada de facturación datos históricos de ventas en energía y usuarios, se realiza una revisión de los datos con el fin de encontrar outliers y corregirlos. Con base en la revisión del estado del arte se escogerán las variables comúnmente utilizadas para pronóstico de demanda de energía y se seleccionarán las que tengan mejor relación con la variable a pronosticar.

**4.3. Actividad 3. Aplicación de modelos.** De acuerdo a la revisión del estado del arte se escogerán 2 modelos para realizar el pronóstico de ventas de energía eléctrica y de usuarios para distintos escenarios y horizontes de tiempo.

**4.4. Actividad 4. Validación de los resultados de los métodos.** Se realizará el pronóstico de ventas de energía eléctrica y de usuarios, de horizontes de tiempo pasado para verificar con diferentes métricas la precisión de los datos.

**4.5. Actividad 5. Comparación de resultados.** Conforme a las métricas se compararán los resultados obtenidos mediante los diferentes modelos con el fin de establecer el modelo para pronóstico de ventas de energía y usuarios con los resultados más acertados.

## **5. ANÁLISIS DE LA SITUACIÓN ACTUAL**

### **5.1. DATOS HISTORICOS**

A continuación se presentan los datos históricos de ventas de energía y número de usuarios del mercado regulado de la Empresa de Energía de Pereira. La empresa define 7 clases de servicio dentro de su mercado con el fin de agrupar a los usuarios con hábitos de consumo similar.

En el presente documento se encuentran los datos de ventas de energía y usuarios del mercado regulado discriminados por clase de servicio para analizar el comportamiento individual de cada una de estas series ya que su estacionalidad, tendencia y tasa variación es independiente, todos los valores se encuentran normalizados con el fin de no comprometer la privacidad de los datos de la empresa. Es de resaltar que todos los datos de ventas de energía y usuarios de mercado regulado se encuentran dentro del operador de red EEP, los usuarios y consumos fuera del operador de red de la empresa se excluyen debido a que el crecimiento de estos no presenta un comportamiento estable sino que es debido a negociaciones directas de la empresa con usuarios en otros operadores de red.

#### **5.1.1. Ventas totales de energía para el mercado regulado**

Para las ventas totales de energía del mercado regulado de la empresa se muestra un gráfico con los datos disponibles que corresponden a las ventas desde enero de 2010 a diciembre de 2016 con periodicidad anual. En la tabla I se puede observar también la variación porcentual para cada clase de servicio para este mismo periodo, con el fin de observar el comportamiento de cada clase de servicio por separado.






Figura 1. Datos históricos de ventas de energía mercado regulado de la Empresa de Energía de Pereira 2010-2016

Tabla I. Variación anual porcentual de ventas de energía del mercado de EEP del periodo 2010 a 2016

Clase de servicio	2011	2012	2013	2014	2015	2016
Residencial	-2.1%	-1.6%	-1.9%	1.9%	2.6%	-1.6%
Áreas Comunes	-0.9%	6.5%	2.4%	5.8%	3.7%	-4.0%
Comercial	3.1%	-2.5%	2.7%	3.8%	5.1%	2.1%
Industrial	1.2%	-3.1%	8.1%	12.8%	17.7%	0.9%
Oficial	0.0%	9.6%	7.5%	5.4%	-4.7%	-8.3%
Alumbrado Público	-	13.9%	30.5%	29.8%	39.0%	13.7%
Provisionales	-17.9%	12.6%	7.2%	10.7%	25.6%	66.6%
<b>Total</b>	<b>-0.3%</b>	<b>-1.3%</b>	<b>0.6%</b>	<b>3.5%</b>	<b>4.3%</b>	<b>-0.2%</b>

Los fenómenos climáticos y el desarrollo económico del país siempre han resultado ser un factor muy influyente para las ventas de energía, lo que corresponde normalmente a un cambio en la tendencia de la serie y pérdida de la estacionalidad de la misma. En el año 2016 se vivió en todo el país una situación crítica desencadenada por el fenómeno del niño ocurrido en el año 2015 y parte de 2016, que ocasionó los niveles más bajos en los embalses en los últimos años, debido a esta situación se implementó una campaña llamada “Apagar paga” con lo cual se logró concientizar a la población colombiana reduciendo la demanda total del SIN en un 5% y así no llegar a la necesidad de realizar racionamientos energéticos. A partir de esta campaña se ha evidenciado la sensibilización de la población en cuanto al consumo eficiente de energía eléctrica, ocasionando una disminución en la energía consumida por los usuarios, especialmente de la clase residencial, que ocupa aproximadamente un 58% de la demanda total regulada de la empresa. Cabe resaltar que los datos utilizados corresponden al mes de facturación, debido a esto

se debe aclarar que los datos de ventas para determinado mes no corresponden a los datos de demanda de ese mismo mes debido a los ciclos de lectura y facturación que maneja la empresa.

- **Ventas de energía para la clase residencial**

Para la clase residencial se puede evidenciar una estacionalidad muy marcada, donde los meses de mayores ventas son diciembre y enero y el de menores ventas es febrero, notándose la pérdida de estacionalidad en años atípicos como 2010, en el cual el país se recuperaba de un fenómeno del niño ocurrido en 2009, y en 2015 y parte de 2016 en los cuales se encontró presente un fenómeno del niño muy marcado.




Figura 2. Ventas de energía Clase Residencial 01-2010 a 10-2017




Figura 3. Dispersión de la estacionalidad de Ventas de energía de la Clase Residencial

- **Ventas de energía para la clase áreas comunes**

Para esta clase de servicio se observa una tendencia levemente creciente donde la única componente estacional que se evidencia es que para la mayoría de los años los meses de mayores ventas corresponden a enero y diciembre y el de menores ventas corresponde a febrero, siendo muy similar a la estacionalidad de a clase residencial. La tendencia de esta serie también se nota afectado por la campaña “apagar paga” a pesar de su crecimiento debido a la entrada de proyectos residenciales como edificios o conjuntos residenciales.




Figura 4. Ventas de energía Clase Áreas Comunes 01-2010 a 10-2017




Figura 5. Dispersión de la estacionalidad de Ventas de energía de la Clase Áreas Comunes

- **Ventas de energía para la clase comercial**

En las ventas de energía de la clase comercial se puede notar que a pesar de la pérdida de estacionalidad de la serie en años atípicos en esta serie se mantiene una tendencia creciente.




Figura 6. Ventas de energía Clase Comercial 01-2010 a 10-2017




Figura 7. Dispersión de la estacionalidad de Ventas de energía de la Clase Comercial

- **Ventas de energía para la clase industrial**

Para la clase industrial no se observa una estacionalidad marcada, debido a que los usuarios industriales tienen consumos atípicos dependientes de negociaciones, condiciones climáticas, TRM, entre otras condiciones típicas de cada tipo de industria, y a la magnitud del impacto que genera el ingreso o retiro de un usuario de alto consumo de esta clase de servicio. En la serie se evidencia también para 2016 y 2017 el decrecimiento que ha tenido la industria manufacturera en la región al igual que en el resto del país.




Figura 8. Ventas de energía Clase Industrial 01-2010 a 10-2017




Figura 9. Dispersión de la estacionalidad de Ventas de energía de la Clase Industrial

- **Ventas de energía para la clase oficial**

Para la clase oficial tampoco se evidencia una estacionalidad marcada, adicionalmente se presenta un gran decrecimiento a partir del año 2015 debido al retiro o cambio de mercado de algunos usuarios de gran consumo.




Figura 10. Ventas de energía Clase Oficial 01-2010 a 10-2017




Figura 11. Dispersión de la estacionalidad de Ventas de energía de la Clase Oficial

- **Ventas totales de energía para la clase Provisional**

La clase de servicio provisional no posee estacionalidad marcada, debido a que el incremento o decremento de estos consumos depende de obras y de la magnitud de estas, las cuales no van asociadas a ninguna estacionalidad.




Figura 12. Ventas de energía Clase Provisionales 01-2010 a 10-2017




Figura 13. Dispersión de la estacionalidad de Ventas de energía de la Clase Provisional

- **Ventas totales de energía para la clase Alumbrado Público**

La clase de servicio alumbrado público no presenta una estacionalidad muy marcada, pero si una tendencia creciente durante todo el intervalo de tiempo tomado, resaltando que para esta clase de servicio se cuenta con datos únicamente desde febrero del 2011.




Figura 14. Ventas de energía Clase Alumbrado Público 01-2010 a 10-2017






Figura 15. Dispersión de la estacionalidad de Ventas de energía de la Clase Alumbrado Público

### 5.1.2. Número de usuarios totales facturados en el mercado regulado EEP

En la siguiente tabla se puede observar la variación porcentual de cada clase de servicio en número de usuarios para el mercado regulado de EEP, en el periodo de 2010 a 2016.

Tabla II. Variación anual porcentual de número de usuarios del mercado de EEP del periodo 2010 a 2016

Clase de servicio	2011	2012	2013	2014	2015	2016
Residencial	3.0%	2.4%	2.8%	3.2%	3.4%	3.7%
Áreas Comunes	5.7%	3.7%	4.9%	5.0%	5.0%	7.6%
Comercial	4.5%	0.8%	1.3%	2.2%	1.0%	6.3%
Industrial	-2.6%	3.3%	3.3%	6.9%	5.7%	6.7%
Oficial	27.5%	6.4%	1.7%	0.0%	2.2%	3.9%
Alumbrado Público	-	0.0%	0.0%	0.0%	0.0%	0.0%
Provisionales	33.9%	2.8%	2.3%	6.8%	14.1%	32.1%
<b>Total</b>	<b>3.3%</b>	<b>2.3%</b>	<b>2.7%</b>	<b>3.1%</b>	<b>3.2%</b>	<b>4.1%</b>

Seguidamente se encuentran las gráficas de las series históricas de usuarios para cada clase de servicio a excepción de la clase Alumbrado Público ya que en esta clase de servicio no hay variación en número de usuarios a lo largo de la serie histórica.

Se puede observar que para la clase de servicio residencial la tasa de crecimiento se comporta de manera muy estable, mientras que para las demás clases de servicio la tasa de crecimiento es muy variable a lo largo del histórico.




Figura 16. Serie histórica de número de usuarios de la clase residencial

En la clase de servicio Áreas Comunes se evidencia un crecimiento muy estable que posee dos grandes incrementos en el año 2015 y 2016 debido al ingreso de proyectos urbanísticos.




Figura 17. Serie histórica de número de usuarios de la clase áreas comunes

La variación de número usuarios para las clases de servicio Comercial e Industrial depende no solamente del crecimiento o decrecimiento de la región en términos comerciales e industriales sino también del cambio de comercializador de algunos usuarios dentro del operador de red EEP de acuerdo a la resolución CREG 183 de 2009




Figura 18. Serie histórica de número de usuarios de la clase comercial




Figura 19. Serie histórica de número de usuarios de la clase industrial




Figura 20. Serie histórica de número de usuarios de la clase oficial

La clase de servicio Provisionales es la más fluctuante a lo largo del tiempo ya que en esta clase de servicio se encuentran todos los usuarios que obtienen una matrícula provisional ya sea para eventos, obras civiles, entre otros; debido a esto en esta clase los usuarios pueden permanecer por periodos de tiempo que dependen de la actividad que vayan a realizar.




Figura 21. Serie histórica de número de usuarios de la clase provisionales

## 5.2. MODELOS ACTUALES DE LA EMPRESA DE ENERGÍA DE PEREIRA

Actualmente en la Empresa de Energía de Pereira no se cuenta con un modelo establecido para proyectar ventas de energía y usuarios, se realiza la proyección mediante promedios de ventas de

años anteriores y se ajusta de acuerdo a la experiencia, para proyectar usuarios se utiliza una regresión lineal simple y se ajusta manualmente de acuerdo a la experiencia.

### **5.3. MODELOS ACTUALES DE OTRAS EMPRESAS DEL SECTOR**

Como parte del proceso de revisión del estado del arte se realiza un acercamiento con diferentes empresas del sector eléctrico con el objetivo de conocer la metodología utilizada para realizar proyecciones, especialmente de ventas de energía. Se logra realizar un acercamiento con dos empresas importantes del sector eléctrico las cuales llamaremos empresa uno y empresa dos.

En la empresa uno se realiza proyección de ventas de energía utilizando regresión lineal, regresión logarítmica e implementan un modelo econométrico para incluir variables exógenas como PIB, con el cual plantean diferentes escenarios para largo plazo, para corto plazo realizan proyección mensual.

En la empresa dos implementan dos tipos diferentes de proyecciones dependiendo del horizonte de tiempo, para largo plazo utilizan un modelo VAR-VEC empleando proyecciones de PIB, proyección de tarifa y una variable dummie para describir fenómenos económicos de gran impacto, el periodo de proyección es anual, para mediano y corto plazo emplean SARIMA y cuentan con una base de datos histórica desde el año 2006.

## 6. MARCO TEÓRICO

### 6.1. METODOS UNIVARIADOS

Los métodos univariados son aquellos que describen el comportamiento futuro de una variable solamente en base a su comportamiento pasado, dejando de lado las variables exógenas y describiendo la serie de manera intrínseca.

#### 6.1.1. Regresión lineal simple

Los modelos de regresión se usan para modelar la relación de una variable dependiente  $Y$  en función de  $n$  variables independientes  $x_1, x_2, x_3, \dots, x_n$ . Entre estos modelos el más sencillo es el de regresión lineal simple. Este método consiste en sumar las diferencias al cuadrado entre los puntos reales y los puntos de la recta a estimar [1]. El método tiene la siguiente ecuación característica:

$$Y = b_0 + bX + \varepsilon \quad (1)$$

Dónde:

$b_0$ : intersección con el eje  $Y$  cuando  $X=0$

$b$ : Pendiente de la recta

$\varepsilon$ : diferencia entre el valor real y el valor estimado




Figura 22. Regresión lineal simple

### 6.1.2. Regresión exponencial

La regresión exponencial se encuentra descrita con la siguiente ecuación:

$$Y = ae^{bx} \quad (2)$$




Figura 23. Regresión exponencial

### 6.1.3. Regresión logarítmica

La regresión logarítmica se encuentra descrita con la siguiente ecuación:

$$Y = b + a \ln x \quad (3)$$




Figura 24. Regresión logarítmica

#### 6.1.4. Regresión cuadrática

La regresión cuadrática se encuentra descrita con la siguiente ecuación:

$$Y = b_0 + b_1x + b_2x^2 + \dots + b_nx^n \quad (4)$$




Figura 25. Regresión cuadrática

#### 6.1.5. Promedios móviles

El método de promedios móviles consiste en promediar una cantidad de datos definida para obtener el pronóstico del dato inmediatamente posterior. Se conoce como móvil debido a que se elimina el dato más antiguo y se incluye el dato anteriormente pronosticado en el rango del promedio para pronosticar el siguiente dato y se continúa moviendo este rango de los datos a promediar para realizar el pronóstico de todos los datos. La operación matemática que describe el método es la siguiente:

$$Y_{t+1} = \frac{1}{n} \sum_{t=0}^{n-1} Y_{t-i} \quad (5)$$

Si la serie presenta un efecto estacional de periodo  $k$  es conveniente aplicar un promedio móvil con  $n = k$  para eliminar la estacionalidad y observar solo la tendencia.



### 6.1.6. ARIMA

El método ARIMA (AutoRegresive Integrate Moving Average) es una generalización del modelo ARMA, es un proceso estocástico desarrollado por George E. P. Box y Gwilym Jenkins el cual une las dos metodologías AR (AutoRegresive) y MA (Moving Average), se encuentra basado en la correlación entre los datos de la serie. Por lo general las series a estudiar tienen asociados procesos aleatorios por lo tanto el estudio de los datos pasados solo sirve para acercarse a la estructura de la serie. Los modelos ARMA solo pueden ser aplicados a procesos estacionarios por lo tanto se utiliza la diferenciación de la serie para obtener una serie estacionaria a partir de una serie no estacionaria pero homogénea [2].

Cada termino AR corresponde al uso de valores rezagados de observaciones pasadas de la serie, este método trata de describir los valores futuros en base a sus observaciones pasadas más un error.

$$AR(p) : Y_t = a_1 Y_{t-1} + a_2 Y_{t-2} + \dots + a_p Y_{t-p} + \varepsilon_t \quad (6)$$

Cada termino MA corresponde al uso de valores rezagados de errores pasados, se asume que el valor futuro puede ser pronosticado en base a los errores pasados

$$MA(q) : Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (7)$$

El método ARIMA contiene un orden de integración I(d) que corresponde a una diferenciación de la serie.

Box y Jenkins recomiendan como mínimo 50 observaciones de la serie a pronosticar. La metodología se resume en 4 etapas:

**Identificación:** Identificar el posible modelo ARIMA que sigue la serie temporal, para lo cual se debe:

- Decidir que transformaciones deben ser aplicadas a la serie para convertirla en una serie estacional.

- Determinar el modelo ARMA, los órdenes p y q a través de las funciones de autocorrelación y autocorrelación parcial. Pueden surgir varios modelos posibles para ser estudiados.

**Estimación:** se selecciona un modelo ARMA provisional, se estiman los parámetros AR y MA por máxima verosimilitud y se obtiene el error estándar y los residuos del modelo.

**Validación:** se realiza un análisis de los residuos para verificar que no sean dependientes y siguen un proceso de ruido blanco (se verifica mediante las gráficas de autocorrelación y autocorrelación parcial), también se realiza una comparación entre los datos arrojados por el modelo seleccionado con datos reales para saber si dicho modelo se ajusta a los datos, de lo contrario realizar la misma validación con otro posible modelo.

**Predicción:** una vez validado el modelo se pueden realizar pronósticos en términos probabilísticos de los valores futuros.

#### 6.1.7. WINTERS

El método de Holt Winters es básicamente un método de suavizamiento exponencial que se encuentra indicado para series con tendencia y estacionalidad. Hace uso de datos históricos para obtener una serie suavizada.

**Modelo multiplicativo:** se presenta cuando el patrón de estacionalidad de los datos depende del tamaño de estos, tal que la estacionalidad aumenta cuando aumenta la magnitud de los datos y disminuye cuando la magnitud de los datos disminuye.

$$\text{Nivel} \quad S_t = \alpha * \left( \frac{D_t}{C_{t+T}} \right) + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (8)$$

$$\text{Tendencia} \quad G_t = \beta * (S_t - S_{t-1}) + (1 - \beta)G_{t-1} \quad (9)$$

$$\text{Factor Estacional} \quad C = \gamma * \left( \frac{D_t}{C_t} \right) + (1 - \gamma)C_{t-T} \quad (10)$$

$$\text{Pronóstico} \quad F_{t+T} = (S_t + \tau G_t)C_{t-T} \quad (11)$$

**Modelo aditivo:** se presenta cuando el patrón de estacionalidad no depende de la magnitud de los datos, la estacionalidad no varía con el aumento o la disminución de la magnitud de los datos.

Cada valor se le asigna un valor entre 0 y 1, cuanto más alto sea el valor más peso se le da a la observación más reciente.

$$\text{Nivel} \quad S_t = \alpha * (D_t - C_{t-T}) + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (12)$$

$$\text{Tendencia} \quad G_t = \beta * (S_t - S_{t-1}) + (1 - \beta)G_{t-1} \quad (13)$$

$$\text{Factor Estacional} \quad C_t = \gamma * (D_t - S_t) + (1 - \gamma)C_{t-T} \quad (14)$$

$$\text{Pronóstico} \quad F_{t+T} = (S_t + \tau G_t)C_{t+\tau-T} \quad (15)$$

## 6.2. INTELIGENCIA ARTIFICIAL

### 6.2.1. Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA) se pueden definir como una técnica de aprendizaje y procesamiento de datos automático que se encuentra inspirado en el cerebro humano. Las redes neuronales artificiales tienen la capacidad de procesar de forma paralela los datos de forma masiva a través de una estructura simple llamada neurona que tiene la capacidad de almacenar conocimiento experimental que puede ser usado posteriormente [5].

La neurona artificial es un elemento que posee un estado interno, llamado nivel de activación y reciben señales que le permiten cambiar de estado [5].

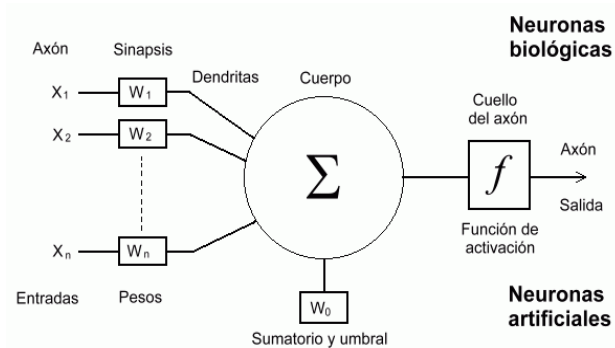


Figura 26. Estructura de una red neuronal artificial [6]

**$X_n$ :** conjunto de entradas

$W_0$ : pesos sinápticos

$\Sigma$ : función de agregación

$f$ : función de activación

### • Arquitectura De La Red Neuronal Artificial

La arquitectura de la red hace referencia a la disposición de las neuronas en la red, estas pueden estar ubicadas en una capa o varias capas de neuronas.

Cada neurona recibe un conjunto de entradas las cuales son multiplicadas por los pesos sinápticos, sumadas y operadas por la función de activación o función de transferencia, para luego transmitir esta información a la siguiente capa o a la salida de la red.




Figura 27. Red con una única capa,  $R$  elementos de entrada y  $S$  neuronas [6]

Habitualmente la arquitectura de las redes neuronales se clasifica en:

**Redes con propagación hacia adelante (feedforward):** en este tipo de red las salidas de las neuronas de una capa solo pueden ser entradas de neuronas de la capa siguiente.

**Redes con retropropagación (feedback):** las salidas de las neuronas pueden ser las entradas de neuronas de la misma capa o de capas previas.

### • Tipo de aprendizaje de la red neuronal

**Aprendizaje supervisado:** utiliza un conjunto de datos conocidos de entrada y salida para ajustar los pesos sinápticos de manera iterativa hasta alcanzar alguno de los criterios de parada, los cuales pueden ser error máximo y número de iteraciones máximas.

**Aprendizaje no supervisado:** la red se entrena únicamente con un conjunto de entradas y salidas de acuerdo a una función de coste a minimizar.

**Aprendizaje reforzado:** la información suministrada a la red es mínima y se limita a indicar si la respuesta es correcta o incorrecta, se encuentra en medio del aprendizaje supervisado y el no supervisado.

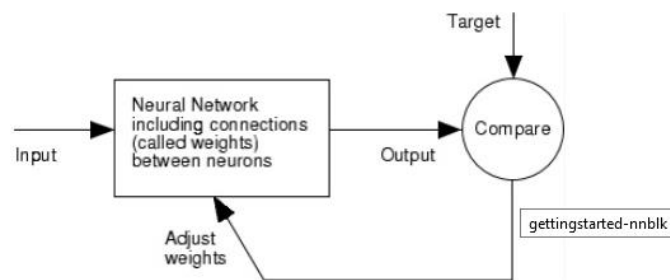


Figura 28. Proceso de ajuste de pesos en el aprendizaje supervisado [6]

### Pasos para la implementación de una red neuronal artificial

- Selección de variables.
- Preprocesamiento de datos.
- Definición del conjunto de entrenamiento, de validación y de prueba.
- Selección de la topología de la red, incluyendo número de neuronas de entrada, número de capas ocultas, número de neuronas de la capa oculta, número de neuronas de salida y función de transferencia o activación.
- Criterios de parada, como número de iteraciones y error máximo admitido.
- Implementación de la red para realizar pronóstico.

## 7. CRITERIOS DE VALIDACIÓN DE LOS METODOS

Para la evaluación del desempeño de las predicciones se emplean diferentes indicadores para cuantificar que tan cerca se encuentra el valor pronosticado al valor real de la serie.

### 7.1. Error residual

El error residual se encuentra definido como la diferencia entre la magnitud real y la magnitud proyectada.

$$e_i = Y_t - \hat{Y}_t \quad (16)$$

Donde:

$Y_t$ : dato real observado en el periodo t

$\hat{Y}_t$ : dato pronosticado para el periodo t

### 7.2. Mean Absolute Desviation - Error Absoluto Medio (MAD)

Proporciona una medición del error promedio en el pronóstico en valor absoluto.

$$\frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \quad (17)$$

Donde:

$Y_t$ : dato real observado en el periodo t

$\hat{Y}_t$ : dato pronosticado para el periodo t

$n$ : número de periodos pronosticados

### 7.3. Root Mean Squared Error – Raíz del Error Cuadrático Medio (RMSE)

Es una medida de desempeño cuantitativo usualmente empleada para evaluar métodos de pronóstico de demanda. El RMSE amplifica y penaliza con más fuerza los errores de mayor magnitud, y el resultado se encuentra expresado en las mismas unidades de la serie pronosticada.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (18)$$

#### 7.4. Mean Absolute Percentage Error – error cuadrado medio (MAPE)

Entrega la desviación en términos porcentuales y no en magnitud como las anteriores métricas. Se calcula como el promedio del error absoluto de los periodos pronosticados, obteniendo así un error expresado como porcentaje de los valores reales.

$$MAPE\% = \frac{\sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t}}{n} * 100 \quad (19)$$

## **8. ESTUDIO DE VARIABLES PARA PRONÓSTICO DE VENTAS DE ENERGÍA**

### **8.1. VARIABLES RELEVANTES**

En la bibliografía se pueden encontrar 3 conjuntos de variables típicamente utilizadas para pronóstico de energía eléctrica.

#### **8.1.1. Variables macroeconómicas**

- Producto Interno Bruto (PIB)
- Tamaño de la Población
- PIB per Cápita

#### **8.1.2. Variables propias del sistema**

- Pérdidas del sistema
- Precio de la Energía

#### **8.1.3. Variables climatológicas**

- Velocidad del Viento
- Humedad Relativa
- Cantidad de Horas de Sol

La selección de las variables a utilizar para el pronóstico de las ventas de energía de la empresa se realiza teniendo en cuenta diferentes criterios, como la correlación de Pearson entre la serie a pronosticar y la variable que se desea emplear, también se tiene en cuenta que esta variable se encuentre proyectada, sea de fácil proyección o la empresa pueda proporcionar esta proyección.

### **8.2. CORRELACIÓN ENTRE VARIABLES**

Para la aplicación de redes neuronales artificiales se realiza un análisis de correlación de las posibles variables de las que se dispone con la serie histórica de cada clase de servicio, adicionalmente se tiene en cuenta la disponibilidad que se tenga de cada variable proyectada al periodo de tiempo que se desean proyectar las ventas de energía. A continuación, se encuentra la tabla de correlación de las series a proyectar con las posibles variables de entrada a utilizar.



Tabla III. Correlación entre variables de entrada y cada clase de servicio

Variable	PIB		Tarifa		Temperatura máx	
Clase de servicio	Correlación de Pearson	Valor P	Correlación de Pearson	Valor P	Correlación de Pearson	Valor P
Residencial	-0.132	0.23	-0.048	0.664	0.355	0.001
Comercial	0.723	0	0.747	0	0.301	0.005
Industrial	0.856	0	0.827	0	0.278	0.011
Oficial	0.474	0	0.16	0.145	0.06	0.589
Áreas Comunes	0.727	0	0.824	0	0.21	0.055
Provisionales	0.77	0	0.582	0	0.172	0.117
Alumbrado Público	0.934	0	0.881	0	0.323	0.006
Variable	Temperatura m		Radiación solar máx		Radiación solar m	
Clase de servicio	Correlación de Pearson	Valor P	Correlación de Pearson	Valor P	Correlación de Pearson	Valor P
Residencial	0.177	0.108	0.165	0.133	-0.058	0.599
Comercial	0.121	0.272	0.064	0.562	0.258	0.018
Industrial	0.076	0.492	0.011	0.92	0.164	0.135
Oficial	0.022	0.844	0.205	0.062	0.105	0.341
Áreas Comunes	0.138	0.21	-0.005	0.963	0.214	0.051
Provisionales	0.131	0.234	0.227	0.038	0.135	0.222
Alumbrado Público	0.146	0.221	0.083	0.49	0.192	0.107

## 9. APLICACIÓN DE MODELOS PARA PRONÓSTICO DE VENTAS DE ENERGÍA

### 9.1. APLICACIÓN DE MODELOS UNIVARIADOS DE TENDENCIA

Inicialmente se aplican algunos métodos univariados como regresión lineal, exponencial, y cuadrática a la muestra de datos de cada serie, que consta de datos de ventas de energía por clase de servicio desde enero de 2010 hasta octubre de 2017, este conjunto se divide en dos subconjuntos que corresponden a datos para regresión (desde enero de 2010 a diciembre de 2016) y datos para validación (enero de 2017 a octubre de 2017). Se emplea el software Minitab 17 para realizar las regresiones, aplicar los métodos de validación a estas regresiones y proyectar para el periodo de validación, posteriormente se aplican los criterios de validación a los datos proyectados.

En la siguiente tabla se encuentran los resultados de la aplicación de los métodos univariados simples para cada clase de servicio, las gráficas de ajuste y pronóstico se encuentran en el anexo A.

Tabla IV. Resultados de aplicación de métodos univariados simples a la serie histórica de ventas de energía por clase de servicio

Clase de servicio	Número de observacion	Tendencia	MAPE		MAD	
			Regresión	Proyección	Regresión	Proyección
Residencial	94	Lineal	2.47%	1.950%	0.00112	0.00839
	94	Cuadrática	2.32%	4.833%	0.01053	0.02108
	94	Exponencial	2.47%	1.946%	0.01118	0.00837
Areas Comunes	94	Lineal	4%	5.482%	0.00087	0.00130
	94	Cuadrática	4%	2.926%	0.00085	0.00069
	94	Exponencial	4%	6.014%	0.00087	0.00143
comercial	94	Lineal	2.86%	1.667%	0.00687	0.00427
	94	Cuadrática	2.46%	5.464%	0.00592	0.01397
	94	Exponencial	2.82%	1.679%	0.00680	0.00430
Industrial	94	Lineal	7.09%	4.011%	0.00366	0.00233
	94	Cuadrática	5.27%	18.833%	0.00270	0.01120
	94	Exponencial	6.82%	4.141%	0.00353	0.00241
Oficial	94	Lineal	7.66%	13.526%	0.00255	0.00434
	94	Cuadrática	6%	6.712%	0.00196	0.00219
	94	Exponencial	7.7%	13.826%	0.00258	0.00444
Provisionales	94	Lineal	24%	7.571%	0.00117	0.00057
	94	Cuadrática	15%	46.690%	0.00077	0.00350
	94	Exponencial	20%	5.988%	0.00103	0.00045
Alumbrado Público	82	Lineal	12%	4.199%	0.00005	0.00004
	82	Cuadrática	7%	13.849%	0.00004	0.00013
	82	Exponencial	8%	11.439%	0.00004	0.00011

## 9.2. APLICACIÓN DE METODO DE WINTERS

Para la aplicación del método de Winters se emplea el Software Minitab 17, se aplica el modelo multiplicativo para tres conjuntos de parámetros  $\alpha$ ,  $\beta$  y  $\gamma$  diferentes por cada clase de servicio, utilizando el conjunto de datos de ventas de energía de enero de 2010 a octubre de 2017, dividido en dos subconjuntos tal como se implementó en el literal anterior.

Tabla V. Resultados de la aplicación del método de Winters por clase de servicio

Clase de servicio	Número de observaciones	Winters			MAPE		MAD	
		$\alpha$	$\beta$	$\gamma$	Regresión	Proyección	Regresión	Proyección
Residencial	94	0.1	0.1	0.1	1.94%	5.75%	0.00878	0.02538
	94	0.2	0.2	0.2	1.66%	6.78%	0.00747	0.02991
	94	0.3	0.3	0.3	1.69%	5.48%	0.00765	0.02412
Areas Comunes	94	0.1	0.1	0.1	3.39%	6.60%	0.00075	0.00159
	94	0.2	0.2	0.2	2.91%	3.94%	0.00065	0.00094
	94	0.3	0.3	0.3	2.91%	3.50%	0.00066	0.00084
comercial	94	0.1	0.1	0.1	2.54%	2.25%	0.00608	0.00577
	94	0.2	0.2	0.2	2.41%	3.39%	0.00579	0.00869
	94	0.3	0.3	0.3	2.61%	2.91%	0.00626	0.00746
Industrial	94	0.1	0.1	0.1	6.63%	3.76%	0.00334	0.00225
	94	0.2	0.2	0.2	4.99%	3.43%	0.00257	0.00206
	94	0.3	0.3	0.3	5.04%	3.61%	0.00260	0.00218
Oficial	94	0.1	0.1	0.1	4.99%	7.61%	0.00163	0.00246
	94	0.2	0.2	0.2	4.34%	9.79%	0.00146	0.00327
	94	0.3	0.3	0.3	4.60%	18.27%	0.00150	0.00610
Provisionales	94	0.1	0.1	0.1	15.43%	18.15%	0.00080	0.00140
	94	0.2	0.2	0.2	15.97%	17.74%	0.00080	0.00137
	94	0.3	0.3	0.3	16.58%	7.78%	0.00090	0.00061
Alumbrado Público	82	0.1	0.1	0.1	8.57%	3.50%	0.00001	0.00003
	82	0.2	0.2	0.2	7.01%	5.66%	0.00004	0.00006
	82	0.3	0.3	0.3	6.99%	3.39%	0.00004	0.00003

En la tabla V se pueden observar los resultados de la aplicación del método de Winters, en el anexo A se pueden observar las gráficas de ajuste y pronóstico de cada clase de servicio.

## 9.3. APLICACIÓN DE REDES NEURONALES ARTIFICIALES

La aplicación del método de redes neuronales artificiales para el pronóstico de ventas de energía se realiza haciendo uso del toolbox Neural Tools de Matlab 2014a, en el cual se escoge como función de activación Bayesian Regularization la cual implementa una red feedforward

Debido a que con este método se obtienen los mejores resultados se realiza el pronóstico de ventas de energía para todas las clases de servicio con una granularidad mensual desde enero de

2017 hasta diciembre de 2022 con los siguientes objetivos: las ventas de energía del periodo de enero de 2017 a octubre de 2017 son usadas para la validación de los métodos, las ventas de energía del periodo de noviembre de 2017 a diciembre de 2018 son empleadas para el presupuesto de la empresa y las ventas de energía del periodo de enero de 2019 a diciembre de 2022 son usadas como insumo para realizar el cálculo de la energía requerida para el mercado regulado EEP en este periodo y de esta manera proceder a la compra de energía.

### 9.3.1. Pronóstico Clase de Servicio Residencial

Para el pronóstico de ventas de energía de la clase de servicio residencial se utiliza como variables de entrada la cantidad de usuarios facturados, la estacionalidad de la serie y una variable dummie de apoyo para los años donde se encuentra presente el fenómeno del niño, la cual es 1 en los años donde este se encuentra presente y 0 para los años donde no se encuentra presente este fenómeno.




Figura 29. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Residencial 11-2017 a 12-2022

Tabla VI. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase residencial

Número de observaciones	Número de neuronas en la capa oculta	Función de activación	MAPE		MAD	
			Entrenamiento	Proyección	Entrenamiento	Proyección
94	7	Bayesian Regularization	0.334%	0.435%	0.00150	0.00191

### 9.3.2. Pronóstico Clase de Servicio Comercial

Para el pronóstico de ventas de energía de la clase de servicio comercial se utiliza como variables de entrada el PIB regional y la estacionalidad de la serie.




Figura 30. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Comercial 11-2017 a 12-2022

Tabla VII. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase comercial

Número de observaciones	Número de neuronas en la capa oculta	Función de activación	MAPE		MAD	
			Entrenamiento	Proyección	Entrenamiento	Proyección
94	8	Bayesian Regularization	0.801%	0.038%	0.001894	0.000098

### 9.3.3. Pronóstico Clase de Servicio Industrial

Para el pronóstico de ventas de energía de la clase de servicio industrial se utiliza como variables de entrada el PIB regional y la estacionalidad de la serie.




Figura 31. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Industrial 11-2017 a 12-2022

Tabla VIII. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase industrial

Número de observaciones	Número de neuronas en la capa oculta	Función de activación	MAPE		MAD	
			Entrenamiento	Proyección	Entrenamiento	Proyección
94	7	Bayesian Regularization	0.102%	0.061%	0.000053	0.000036

#### 9.3.4. Pronóstico Clase de Servicio Oficial, Áreas Comunes y Provisional

Para el pronóstico de ventas de energía de las clases de servicio oficial, áreas comunes y provisional, no se hace posible proyectar estas clases de servicio por separado debido a que las clases de servicio áreas comunes y provisional representan una porción muy pequeña de las ventas, y particularmente para la clase de servicio provisional no se presenta una estacionalidad marcada.




Figura 32. Serie histórica 01-2010 a 10-2017 y pronóstico de ventas de la clase de servicio Otros 11-2017 a 12-2022

Tabla IX. Resultados de aplicación de RNA a la serie histórica de ventas de energía de las clases áreas comunes, oficial y provisionales

Número de observaciones	Número de neuronas en la capa oculta	Función de activación	MAPE		MAD	
			Entrenamiento	Proyección	Entrenamiento	Proyección
94	9	Bayesian Regularization	0.002%	0.004%	0.0000012	0.0000023

### 9.3.5. Pronóstico Clase de Servicio Alumbrado Público

Para el pronóstico de ventas de energía de la clase de servicio alumbrado público se utiliza como variables de entrada el PIB regional y la estacionalidad de la serie.




Figura 33. Serie histórica 01-2011 a 10-2017 y pronóstico de ventas de la clase de servicio Alumbrado Público 11-2017 a 12-2022

Tabla X. Resultados de aplicación de RNA a la serie histórica de ventas de energía de la clase alumbrado público

Número de observaciones	Número de neuronas en la capa oculta	Función de activación	MAPE		MAD	
			Entrenamiento	Proyección	Entrenamiento	Proyección
73	8	Bayesian Regularization	0.204%	0.000%	0.0000005	0.0000000



## **10. APLICACIÓN DE MODELOS UNIVARIADOS Y ESTADÍSTICOS PARA PROYECCIÓN DE USUARIOS**

Para la proyección de usuarios del mercado regulado se decide implementar únicamente métodos univariados debido a que no se cuenta con variables que incidan sobre la serie, adicionalmente para la mayoría de series se obtienen buenos resultados aplicando métodos univariados.

Se dispone de datos mensualizados de número de usuarios desde enero de 2010 a octubre de 2017, los cuales se dividen de la misma forma que se realizó para pronóstico de ventas de energía, un subconjunto de datos para regresión (datos con periodicidad mensual desde enero de 2010 a diciembre de 2016) y subconjunto para proyección (datos con periodicidad mensual desde enero de 2017 a octubre de 2017), la granularidad del número de usuarios se realiza de forma mensual debido a que el número de usuarios se utiliza como variable de entrada para algunos pronósticos de ventas de energía. Se realiza la proyección de usuarios por clase de servicio debido a que cada clase de servicio tiene una tasa de variación diferente como se ha mencionado anteriormente; no obstante, no se realiza proyección para la clase de servicio alumbrado público ya que en esta clase no ha variado el número de usuarios a lo largo del histórico de datos con el que se cuenta.

Tabla XI. Resultados de proyección de usuarios del mercado regulado EEP por clase de servicio

Clase de servicio	Número de observacion	Tendencia	MAPE		MAD	
			Regresión	Proyección	Regresión	Proyección
Residencial	94	Lineal	1.00%	1.192%	0.00371	0.00999
	94	Cuadrática	0.00%	0.458%	0.00276	0.00379
	94	Exponencial	0.00%	0.723%	0.00303	0.00603
Areas Comunes	94	Lineal	1.14%	2.111%	0.06015	0.00013
	94	Cuadrática	0.93%	0.364%	0.04775	0.00002
	94	Exponencial	0.94%	0.862%	0.04891	0.00005
comercial	94	Lineal	0.70%	3.307%	0.00058	0.00298
	94	Cuadrática	0.70%	3.375%	0.00059	0.00305
	94	Exponencial	0.70%	3.081%	0.00060	0.00278
Industrial	94	Lineal	3.29%	6.731%	0.14537	0.00036
	94	Cuadrática	0.78%	2.231%	0.00003	0.00012
	94	Exponencial	3.13%	6.557%	0.13883	0.00036
Oficial	94	Lineal	5%	6.328%	0.00018	0.00027
	94	Cuadrática	3%	4.696%	0.00011	0.00020
	94	Exponencial	5%	8.851%	0.00020	0.00038
Provisionales	94	Lineal	7%	10.616%	0.00012	0.00026
	94	Cuadrática	8%	5.344%	0.00012	0.00013
	94	Exponencial	8%	6.268%	0.00012	0.00015

Es de notar que para las clases de servicio oficial y provisionales se encuentra un error relativamente alto debido a que el número de usuarios es pequeño y como se puede observar en las figuras 20 y 21, a lo largo de la serie se encuentran cambios bruscos y decrecimientos.

## 11.COMPARACIÓN DE LOS RESULTADOS OBTENIDOS CON LOS DIFERENTES METODOS

### 11.1. COMPARACIÓN DE RESULTADOS OBTENIDOS PARA PRONÓSTICO DE VENTAS DE ENERGÍA POR CLASE DE SERVICIO

Para la comparación de los resultados se emplean los criterios de validación error cuadrado medio porcentual (MAPE) y el error absoluto medio (MAD), los cuales se aplican al pronóstico realizado con cada uno de los métodos para cada clase de servicio. El pronóstico para cada una de las clases de servicio corresponde a los datos de ventas de energía del periodo comprendido entre enero de 2017 a octubre de 2017 con una granularidad mensual, esto debido a que el comportamiento de las series de datos poseen un componente tanto estacional como aleatorio.

Debido a que para realizar proyección mediante el método de redes neuronales artificiales fue necesario agrupar las clases de servicio áreas comunes, oficial y provisionales, se realiza la proyección de esta agrupación con los diferentes métodos univariados para así poder realizar una comparación acertada.

Tabla XII. Comparación de resultados obtenidos con los diferentes métodos aplicados para pronóstico de ventas de energía

Clase de servicio	Criterio de validación	Lineal	Cuadrática	Exponencial	Winters			RNA
					$\alpha=\beta=\gamma=0.1$	$\alpha=\beta=\gamma=0.2$	$\alpha=\beta=\gamma=0.3$	
Residencial	MAPE	1.95%	4.83%	1.95%	5.75%	6.78%	5.48%	0.44%
	MAD	0.0084	0.0211	0.0084	0.0254	0.0299	0.0241	0.0019
Comercial	MAPE	1.67%	5.46%	1.68%	2.25%	3.39%	2.91%	0.04%
	MAD	0.0043	0.0140	0.0043	0.0058	0.0087	0.0075	0.00010
Industrial	MAPE	4.01%	18.83%	4.14%	3.76%	3.43%	3.61%	0.06%
	MAD	0.00233	0.01120	0.00241	0.0023	0.0021	0.0022	0.00004
Alumbrado Público	MAPE	4.20%	13.85%	11.44%	3.50%	5.66%	3.39%	0%
	MAD	0.00004	0.00013	0.00011	0.00003	0.00006	0.00003	3.2E-09
Areas comunes, oficial y provisionales	MAPE	2.24%	3.21%	2.42%	1.07%	1.87%	3.25%	0.004%
	MAD	0.0014	0.0020	0.0015	0.0007	0.0012	0.0021	0.000002

Como se puede observar en la tabla XIII los mejores resultados para todos los pronósticos se obtienen a través del método de redes neuronales artificiales; se puede notar también que a través de algunos métodos univariados de tendencia simple se obtienen resultados con error bajo, a pesar de esto no son considerados métodos acertados debido a que no respetan la estacionalidad de las series (ver anexo A).

## 11.2. COMPARACIÓN DE RESULTADOS OBTENIDOS PARA PROYECCIÓN DE USUARIOS

Para la comparación de los resultados se emplean los criterios de validación error cuadrado medio porcentual (MAPE) y el error absoluto medio (MAD), los cuales se aplican a la proyección realizada con cada uno de los métodos aplicados para cada clase de servicio. La proyección para cada una de las clases de servicio corresponde a los datos de número de usuarios del mercado regulado del periodo comprendido entre enero de 2017 a octubre de 2017 con una granularidad mensual, esto debido a que el número de usuarios se emplea como variable de entrada para el pronóstico de ventas de energía a través de redes neuronales artificiales.

Tabla XIII. Comparación de resultados obtenidos con los diferentes métodos aplicados para proyección de usuarios

Clase de servicio	Criterio de validación	Lineal	Cuadrática	Exponencial
Residencial	MAPE	1.19%	0.46%	0.72%
	MAD	0.0100	0.0038	0.0060
Areas Comunes	MAPE	2.11%	0.36%	0.86%
	MAD	0.0001	0.0000	0.0001
Comercial	MAPE	3.31%	3.37%	3.08%
	MAD	0.0030	0.0030	0.0028
Industrial	MAPE	6.73%	2.23%	6.56%
	MAD	0.00036	0.00012	0.00036
Oficial	MAPE	6.33%	4.70%	8.85%
	MAD	0.00027	0.00020	0.00038
Provisionales	MAPE	10.62%	5.34%	6.27%
	MAD	0.0003	0.0001	0.0002

Se puede observar que para la mayoría de los casos el mejor ajuste se obtiene con el método de tendencia cuadrática, a pesar de esto no es muy efectivo para clases de servicio con pocos usuarios y grandes variaciones como lo es la clase de servicio oficial y provisionales.

## 12.CONCLUSIONES

La aplicación de métodos como regresión lineal simple, exponencial y cuadrática para el pronóstico de ventas de energía eléctrica en la Empresa de Energía de Pereira no son efectivos ya que al tomar las ventas con una periodicidad mensual no obedecen a ninguno de estos comportamientos, además de que estas series se ven influenciadas por otras variables.

Se comprueba que, entre los métodos aplicados, el que presenta un mejor ajuste para pronóstico de ventas de energía es el método de redes neuronales artificiales ya que permite incluir diferentes variables que influyen sobre la serie de datos y aprende de su comportamiento pasado para así obtener un pronóstico más acertado.

Actualmente el limitante en los pronósticos mediante métodos multivariados es encontrar variables de entrada para el modelo con una alta correlación con la serie de ventas de energía que se desea proyectar, adicionalmente se debe contar con proyecciones de estas variables al mismo periodo de tiempo que se desee pronosticar la serie de ventas de energía y el resultado del pronóstico se encuentra netamente ligado a la correcta proyección de las variables de entrada.

Se observa que, para la proyección de usuarios, para las clases de servicio con pocos usuarios el error supera el 5% independientemente del método utilizado debido a la variación que han tenido las series históricas.

Para realizar una proyección de usuarios más acertada se requiere una base de datos que cuente con variables como plan de expansión territorial, proyectos de vivienda, urbanizaciones, etc., como también variables asociadas al desarrollo de los sectores económicos

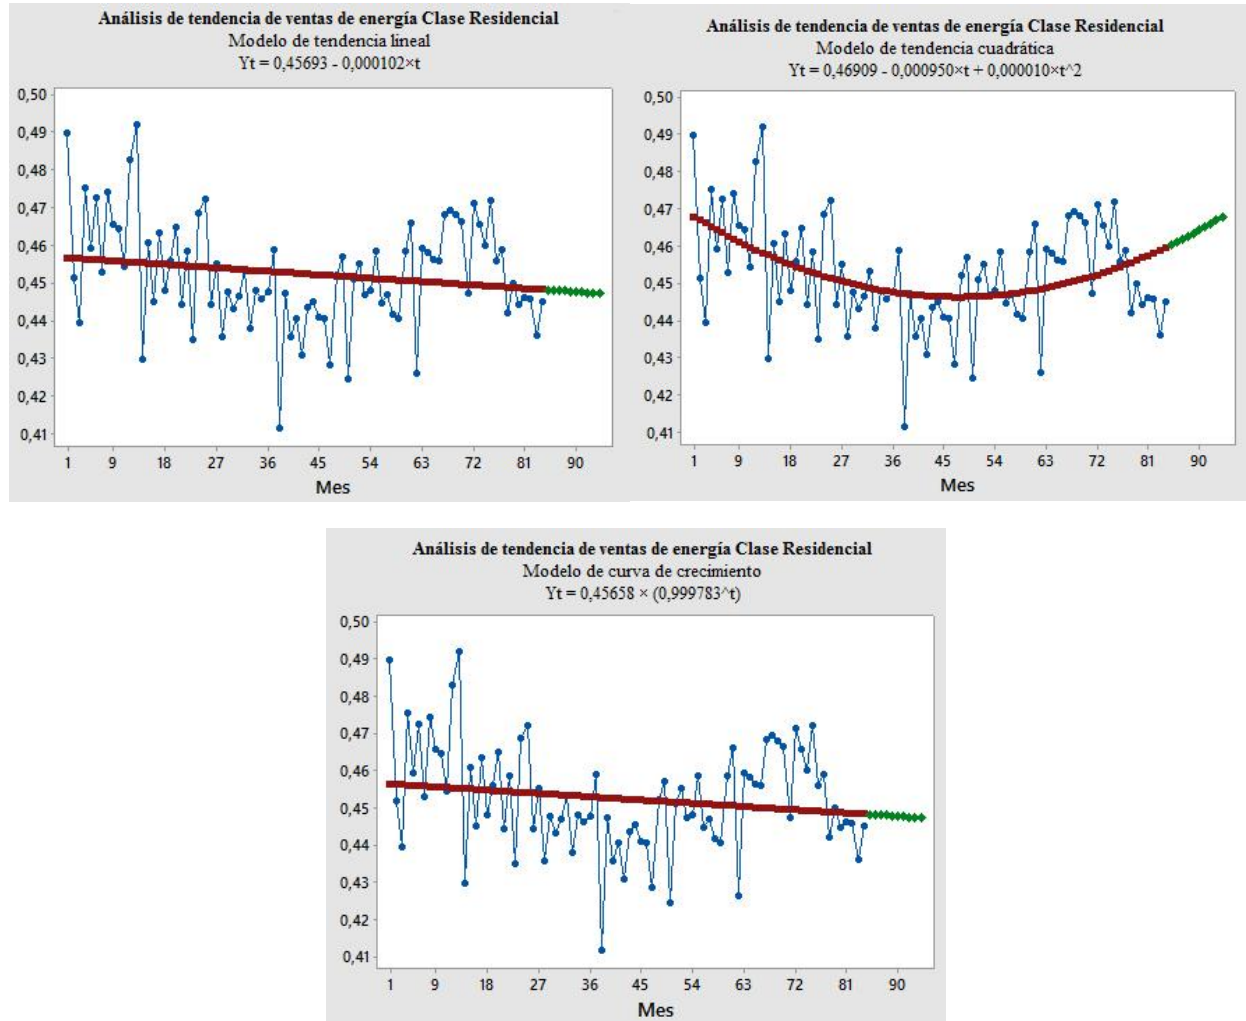
### 13.BIBLIOGRAFÍA

- [1] D. R. Anderson, D. J. Sweeney, T. A. Williams. “Estadística para administración y economía”. Cengage Learning, 2008, Capítulo 10.
- [2] S. de la Fuente, “Series de tiempo: modelo ARIMA”, Facultad de Ciencias Económicas y Empresariales, Universidad Autónoma de Madrid.
- [3] I. A. Basheer, M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application”, El Sevier, Journal of Microbiological Methods 43, 2000, pp 3-31.
- [4] A.F. Palma, “Pronóstico de demanda de energía y potencia eléctrica en el largo plazo para la red de Chilectra s.a. utilizando técnicas de minería de datos”, tesis para optar al grado de magíster en gestión de operaciones, Depto. de ing. Ind., facultad de ciencias físicas y matemáticas, Univ. de Chile 2015.
- [5] A.M. Ariza, “Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución”, trabajo presentado como proyecto de grado para optar al título de Ingeniera Electricista, Prog. de ing. eléctrica, Facultad de ingenierías: eléctrica, electrónica, física y ciencias de la computación, Universidad Tecnológica de Pereira, Pereira, Rld.
- [6] P. Isasi and I.M. Galván, “Redes neuronales artificiales. Un enfoque práctico”, Madrid: Prentice Hall, 2004, capítulo 7, pp 171-184.
- [7] “Redes Neuronales Artificiales con MATLAB”, Mathworks, 2017. [En línea]. Disponible en: <https://la.mathworks.com/discovery/redes-neuronales.html>
- [8] A. Huerta V., J.C. Quispe H., E.M. Ramos C., Y. Molina, “Aplicación de redes neuronales para el pronóstico de la demanda a corto plazo”, XVIII International Congress of Electronic, Electrical and Systems Engineering, Lima, Perú, 2011.
- [9] R. Stucchi, “Breve Introducción a EViews”, (Versión Preliminar), 2006.

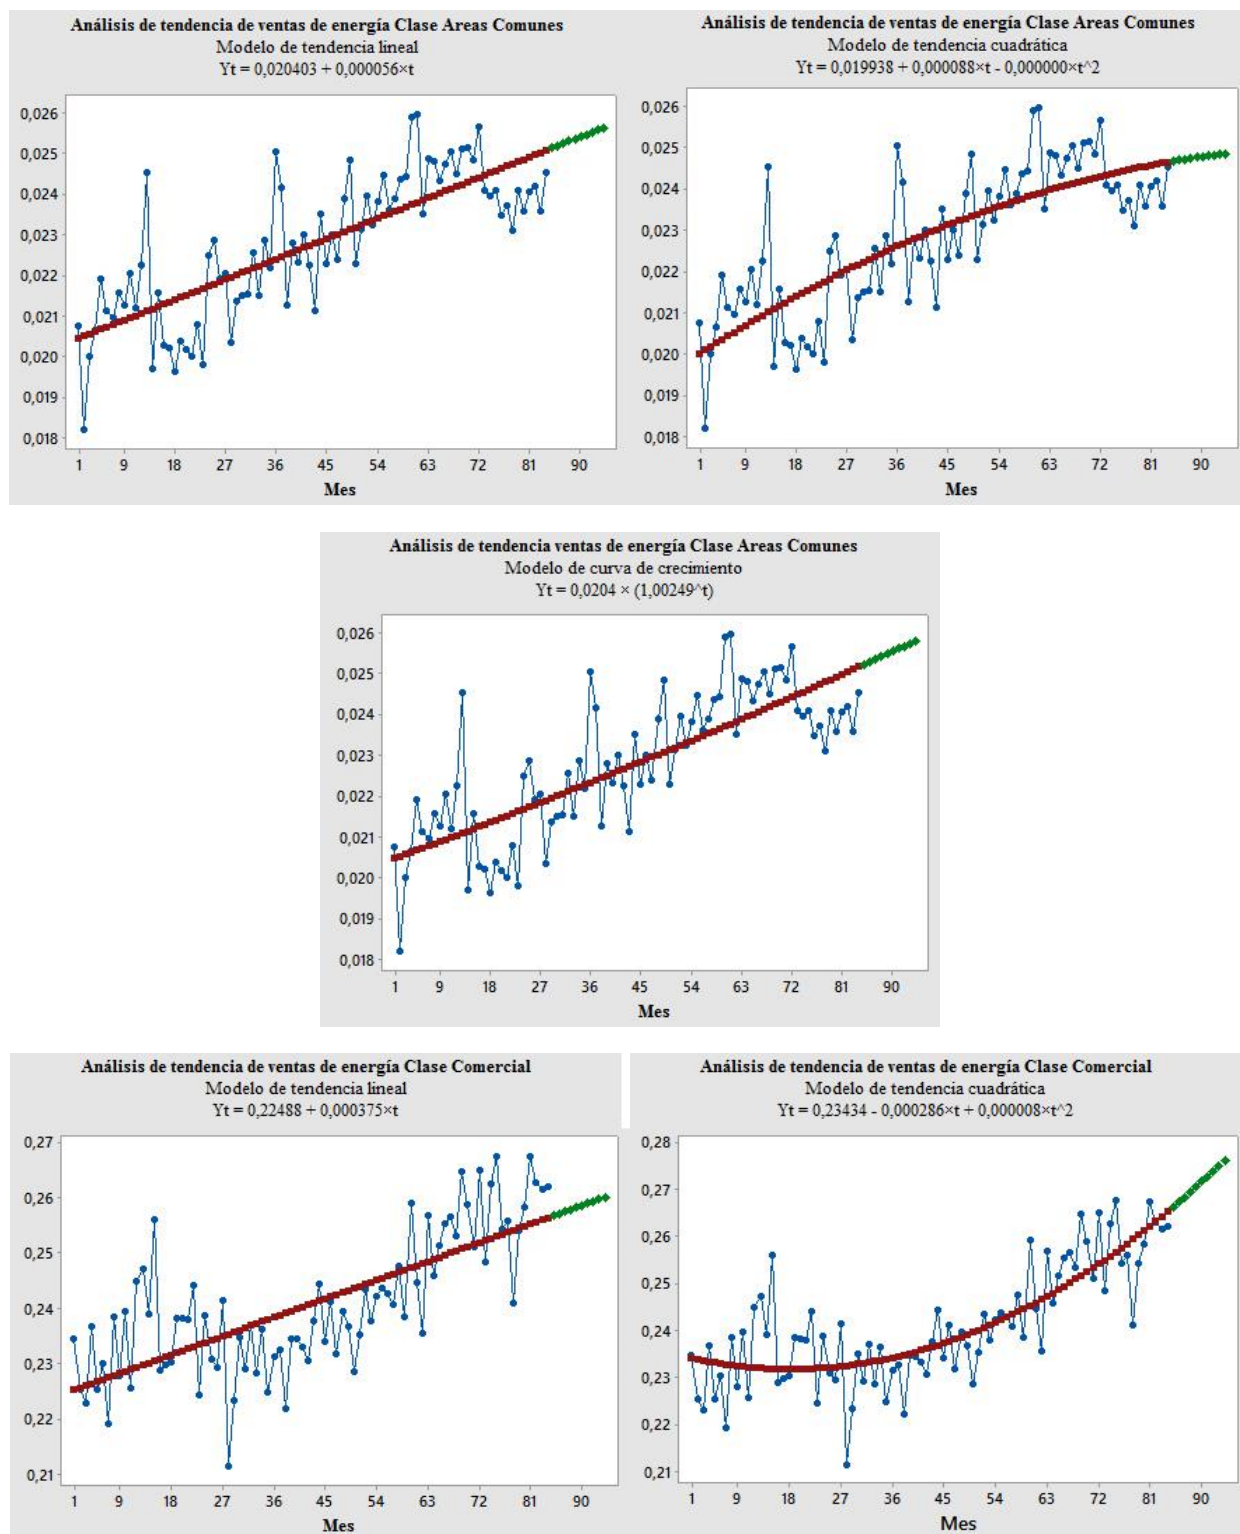
- [10] J. Murillo S., A. Trejos, P. Carvajal O., “Estudio del pronóstico de la demanda de energía eléctrica, utilizando modelos de series de tiempo”, Scientia et Technica Año IX, No 23, Diciembre 2003.
- [11] M. Chonga, R. Aguilar, “Proyección de Series de Tiempo para el Consumo de la Energía Eléctrica a Clientes Residenciales en Ecuador”, Concepción, Chile, Revista Tecnológica ESPOL – RTE, Vol. 29, N. 1, 56-76, Julio 2016.
- [12] G. Ríos, “Series de tiempo”, Depto. de Ciencias de la Computación, Facultad de ciencias físicas y matemáticas, Univ. de Chile, 2008.
- [13] “Proyecciones nacionales y departamentales de población 2005-2020”, Departamento Administrativo Nacional de Estadística (DANE), Bogotá, 2009.




## ANEXO A




Gráficas de la aplicación de los métodos de tendencia aplicados a las series de ventas de energía por clase de servicio.
















Gráficas de la aplicación del método de Winters multiplicativo aplicado a las series de ventas de energía por clase de servicio.

